



**David RECHAL**

***Rapport de stage***

**MASTER Professionnel TAPE~TGAE  
Université Pierre et Marie Curie – Paris VI**

***Analyse du potentiel des classifications de type  
SVM pour l'identification des parcelles arborées  
dans les images de télédétection à très haute  
résolution spatiale***

17 Mars 2008 – 12 Septembre 2008

Encadrant : Camille LELONG (chercheur CIRAD)



## REMERCIEMENTS

Je tiens à remercier toutes les personnes qui ont permis le bon déroulement de mon stage à la Maison de la Télédétection.

Mes premiers remerciements s'adressent à Madame Camille LELONG, chercheur en Télédétection, pour avoir accepté d'être mon maître de stage et pour toutes les connaissances qu'elle m'a apportées.

Mes autres remerciements s'adressent à :

Pascal KOSUTH, directeur de l'UMR TETIS, pour son accueil au sein du laboratoire.

Le CNES pour avoir financé ce projet qui a fait l'objet de mon stage. En particulier Jordi Inglada pour sa disponibilité et ses explications quant à l'ORFEO Toolbox, ainsi que Cyrille VALLADEAU de l'équipe de CS Systèmes d'information.

Monsieur B. Mougél pour son aide dans le calcul des paramètres de Fourier des données.

Monsieur Alain CLOPES, administrateur système de la MTD, pour l'installation de mon environnement de travail ainsi que pour son aide technique.

Mesdames N. JEAN et A. HUGUET pour leur soutien dans les différentes démarches administratives.

Les nombreux stagiaires présents comme moi à la MTD, pour leur bonne humeur, notamment ceux qui partageaient mes pauses "café".

Sans oublier le cuisinier de la cantine du CIRAD, pour les bons plats qu'il a su préparer !!!

## RÉSUMÉ

Cette étude repose sur la mise en place d'une méthode de classification des arbres fruitiers et de différents types de cultures sur des images à Très Haute Résolution Spatiale (THRS) et ce à partir de l'algorithme SVM (Séparateur à Vaste Marge) qui est basé sur l'utilisation de différentes fonctions noyaux. Les différentes parcelles présentes dans les images sont extraites et considérées comme des objets. La classification est faite sur ces parcelles en tenant compte de leur contenu en informations spatiales et spectrales : l'information spatiale est traduite par des indices de texture et des paramètres de Fourier, l'information spectrale est traduite par l'indice de végétation normalisé. Le potentiel de la méthodologie est évalué en testant différentes fonctions noyaux (polynomial, linéaire, gaussien, sigmoïdal) et différents paramétrages de l'algorithme. Le but de l'étude est de déclarer, à partir des résultats optimums, si une classification basée sur les SVM est adaptée à la discrimination des parcelles arborées dans les données à THRS.

## TABLE DES MATIERES

<b>REMERCIEMENTS .....</b>	<b>ii</b>
<b>RÉSUMÉ .....</b>	<b>iii</b>
<b>GLOSSAIRE .....</b>	<b>vi</b>
<b>CHAPITRE-1 INTRODUCTION.....</b>	<b>2</b>
1.1. Organisme d'accueil .....	2
1.2. Structure d'accueil .....	2
1.3. Contexte de l'étude.....	3
1.4. Objectif du stage .....	4
<b>CHAPITRE-2 DONNEES .....</b>	<b>5</b>
2.1 Zones étudiées.....	5
2.2 Images utilisées .....	5
2.3 Données de terrain et classification vérité-terrain .....	7
<b>CHAPITRE-3 METHODOLOGIE.....</b>	<b>9</b>
3.1 Méthode de classification .....	9
3.1.1 État de l'art.....	9
3.1.2 L'algorithme de classification SVM .....	10
3.1.3. Optimisation des SVM.....	11
3.2 Choix des descripteurs .....	11
3.2.1 Indices de texture.....	11
3.2.2 Paramètres de Fourier .....	13
3.2.3 NDVI.....	15
3.3 Analyse .....	15
<b>CHAPITRE-4 RESULTATS ET DISCUSSION.....</b>	<b>18</b>
4.1 Matrices de confusion .....	18
Noyau RBF .....	18
Noyau linéaire .....	19
Noyau sigmoïdal .....	20
Noyau polynomial .....	22
4.2 Discussion .....	23
<b>CHAPITRE-5 CONCLUSION ET PERSPECTIVES .....</b>	<b>25</b>

Liste des tableaux.....	26
Table des figures .....	27
Liste des graphiques.....	28
BIBLIOGRAPHIE .....	29
ANNEXES .....	I

## GLOSSAIRE

MTD	Maison de la Télédétection
CIRAD	Centre de Coopération Internationale en Recherche Agronomique pour le Développement
CEMAGREF	Centre national du Machinisme Agricole, du Génie Rural, des Eaux et des Forêts
ENGREF	Ecole nationale du Génie Rural des Eaux et des Forêts
IRD	Institut de Recherche et Développement
UMR	Unité Mixte de Recherche
TETIS	Territoires, Environnement, Télédétection et Information Spatiale
US	Unité de Service
ESPACE	Expertise et SPAtialisation des Connaissances sur Environnement
LCT	Laboratoire Commun de Télédétection
SIG	Système d'Information Géographique
THRS	Très Haute Résolution Spatiale
ENVI	ENvironment for Vizualing Images Research Systems
NDVI	Normalized Difference Vegetation Index
SVM	Séparateur à Vaste Marge (ou Support Vector Machine)
TAPE	Télédétection Appliquée aux Problèmes Environnementaux
TGAE	Télédétection et Géomatique Appliquée à l'Environnement



## CHAPITRE-1 INTRODUCTION

### 1.1. Organisme d'accueil

Le CIRAD ou Centre de Coopération Internationale en Recherche Agronomique pour le Développement (<http://www.cirad.fr>) est un institut de recherche français classé dans la catégorie des établissements publics à caractères industriel et commercial (EPIC). Il a été créé en 1984 par le regroupement de neuf instituts de recherche agronomique appliquée aux régions chaudes. Sa mission est de contribuer au développement rural des pays tropicaux et subtropicaux par des actions de recherche, des réalisations expérimentales, des actions de formation (France et étranger) ou encore la diffusion d'information scientifique et technique en privilégiant les actions en partenariat. Ses compétences relèvent des sciences du vivant, des sciences humaines et des sciences de l'ingénieur, appliquées à l'agriculture et l'alimentation, à la gestion des ressources naturelles et aux sociétés. Il comprend trois départements (Systèmes BIOlogiques, PERformances des SYSTèmes de production et de transformation tropicaux, Environnement et Sociétés) regroupant 56 unités : 27 unités propres de recherches (UPR), 4 unités de service (US), 22 unités mixtes de recherche (UMR, dont l'UMR TETIS, intégrée au département ES), et 3 unités de recherches en partenariat (URP). Le CIRAD intervient par des recherches et expérimentations, des actions de formation, d'information et d'innovation, et des expertises.

### 1.2. Structure d'accueil

Mon stage s'est déroulé à la Maison de la Télédétection en Languedoc-Roussillon (MTD), localisée à Montpellier. Créée en 1994 par l'Etat, la Région Languedoc-Roussillon et avec l'aide de l'Union Européenne, cette structure regroupe différentes équipes présentes sur le site d'Agropolis autour d'un pôle unique de compétences spécialisé en géomatique.

Elle rassemble des agents du CEMAGREF, de l'ENGREF, du CIRAD, et de l'IRD, ainsi que de petites entreprises privées (exemple : l'Avion Jaune, Nev@ntropic), soit une cinquantaine de permanents, une trentaine de doctorants, scientifiques étrangers, personnels sur contrats et une trentaine de stagiaires accueillis chaque année. Ces organismes sont structurés en deux unités : l'UMR TETIS (Unité Mixte de Recherche CIRAD/CEMAGREF/ENGREF « Territoires, Environnement, télédétection et Information Spatiale ») et l'U.S ESPACE (Unité de Service IRD « Expertise et SPAtialisation des Connaissances sur l'Environnement »).



Maison de la Télédétection  
500 rue Jean-François Breton  
34398 Montpellier



J'ai été accueilli par le CIRAD, au sein de l'UMR TETIS (<http://www.tetis.teledetection.fr>) et encadré par Camille Lelong, chercheur en télédétection. Cette unité, dirigée par Pascal KOSUTH, mène des recherches orientées vers la télédétection, l'analyse et la représentation spatiale de systèmes agroenvironnementaux et territoriaux, la gestion de l'information et sa mobilisation pour le développement, en France, en Europe et dans les régions tropicales. Elle dispense également des formations initiales d'ingénieur, de Mastère spécialisé, de Master universitaire et des formations professionnelles continues ou à distance. Les projets sont montés en partenariat avec différents acteurs de la gestion de l'environnement et de l'aménagement du territoire (services de l'Etat, collectivités territoriales) ainsi qu'avec les acteurs économiques et professionnels (industries du secteur spatial, opérateurs privés et bureaux d'études).

### **1.3. Contexte de l'étude**

La classification d'image est un outil important pour l'interprétation des images en télédétection et la cartographie. L'augmentation de la résolution spatiale avec l'arrivée des satellites tels qu'Ikonos (1999, 1m), EROS A (2000, 1,8m), EROS B (2006, 0,70m), ou Quickbird (2001, 0,70m), permet d'avoir des images donnant une représentation très détaillée des objets observés. Cependant les techniques d'interprétation et de classification utilisées pour les images à moindre résolution spatiale, telles que celles obtenues par les satellites Landsat ou SPOT (de 10m à 30m) ne sont pas adaptées aux données à très haute résolution spatiale (THRS). En effet, ces méthodes, dites « classification par pixel », permettent de classer les pixels de l'image en fonction de leur valeur numérique (information spectrale, voire texturale). Avec la THRS, il y a une augmentation considérable du nombre d'objets ou de détails observés, ainsi que des informations « parasites » comme l'ombre des objets. De plus, la petite taille des pixels de ce type de données (plus petite que la plus part des objets observés) entraîne la définition d'un même objet sur plusieurs pixels ; il en résulte une grande variabilité spectrale pour des objets d'une même classe et une discontinuité de l'information. Ces éléments provoquent une faiblesse des classifications « classiques » si la méthode utilisée n'en tient pas compte efficacement [1,2]. Il est donc rapidement devenu nécessaire de développer des techniques de classification adaptées à ce type d'information. Idéalement, la méthode la plus efficace reste la photointerprétation, mais elle implique des durées de traitements extrêmement longs et une expertise poussée du photointerprète qui ne conduit pas à un espoir d'automatisation des protocoles. Les chercheurs se tournent donc vers de nouvelles approches, comme la classification orientée objet ou les méthodes de classification contextuelle [3] qui permettent l'analyse d'un pixel dans son environnement. Des méthodes de traitement basées sur l'analyse de texture [4], ou sur l'analyse fréquentielle [5] lorsque les objets observés présentent une certaine périodicité, sont également proposées. On retrouve aussi dans la littérature des approches basées sur la morphologie mathématique utilisée par exemple dans des cas d'extraction urbain [6].

Depuis quelques années, l'UMR TETIS développe des méthodes de traitement semi-automatique permettant d'identifier, cartographier et caractériser les parcelles arborées dans les images à THRS (Projet financé par le Programme National de Télédétection Spatiale, thèse de B. Mougél cofinancée par le CNES et l'IGN, études ponctuelles financées par le programme ORFEO du CNES). Elle travaille en particulier sur une chaîne de traitement de ces données passant par une première étape de segmentation afin d'extraire les zones homogènes du point de vue de l'utilisation du sol (les « parcelles »), suivie d'une étape de classification des parcelles comme objets uniques, et non pas des pixels. Afin de discriminer ces parcelles, celles-ci sont caractérisées par différents descripteurs, calculés à l'échelle de la parcelle dans son ensemble, comme par exemple les paramètres de la transformée de Fourier locale, des indices de textures pertinents ou encore des indices de végétation.

C'est donc dans ce contexte thématique que s'est déroulé mon stage, dont l'objectif est développé dans le paragraphe suivant.

#### **1.4. Objectif du stage**

L'objectif de mon stage est d'évaluer les algorithmes de classification basés sur le "Séparateur à Vaste Marge" (SVM, voir chapitre 4) permettant de discriminer différentes espèces d'arbres fruitiers dans les images à THRS. La méthode est développée à partir d'une extraction des parcelles, puis de la détermination de descripteurs permettant de caractériser leur structure spatiale et spectrale, de la mise en place de la structure des données à classer et enfin du choix de l'algorithme de classification. Le potentiel de cette méthodologie sera ensuite évalué: les résultats attendus sont, d'une part, une bonne discrimination des cultures arborées et des autres types d'occupation du sol (friches, sols nus, etc, ...) et, d'autre part, la possibilité d'établir une typologie des différentes cultures arborées présentes dans les scènes d'étude. A cet effet, deux images tests seront analysées, présentant chacune des types de plantations très différents (cf. chapitre 2).

## **CHAPITRE-2    DONNEES**

### **2.1    Zones étudiées**

L'étude menée au cours de ce stage a pour contexte géographique les zones méditerranéennes et tropicales.

La première zone de tests est un paysage agricole se situant sur la commune de Saint-Gilles, au Sud de Nîmes dans le département du Gard (cf. Annexe 1). Elle présente une très grande variété de vergers en termes d'espèces, de densités et d'âges de plantation. Elle contient en outre des parcelles assez faciles à discriminer par photo-interprétation grâce à leur géométrie et structure précises. Elle constitue ce que l'on pourrait appeler un "cas d'école" pour cette étude.

La deuxième zone de tests correspond à la station fruitière du CIRAD de Vieux-Habitants (cf. Annexe 2), localisée au Sud-ouest de la Guadeloupe au niveau de la « côte sous le vent ». Cette zone présente une complexité plus grande que la première au niveau des parcelles, en raison d'une géométrie et d'une structure pas toujours très précise et de la présence de nombreuses surfaces non cultivées sur l'image. Les types d'arbres (taille, forme) et leur organisation sont très différentes de ceux de la première zone, ce qui offre une gamme de variabilité élargie à des contextes tropicaux plus complexes.

### **2.2    Images utilisées**

Les images analysées ont été acquises par le capteur satellite Quickbird. Celui-ci atteint une résolution spatiale de 70 centimètres en mode panchromatique et de 2,5 mètres en mode multispectral. La donnée multispectrale a donc été fusionnée à l'image panchromatique suivant la méthode de Brovey implémentée sous ENVI, de manière à obtenir une image multispectrale à THRS. C'est toutefois le mode panchromatique qui présente le plus d'information de structures et de formes. L'information spectrale pourra être utilisée sous forme d'indices de végétation, pour permettre de discriminer des objets d'apparence identiques mais d'états de surface différents.

Les arbres fruitiers présents dans les contextes géographiques de l'étude (Sud de la France et Antilles) sont pour la plupart de gros arbres (oliviers, cerisiers, manguiers, corossoliers, sapotiers, etc, ...) ayant une taille de houppier (jusqu'à 3 à 5m) largement supérieure à la résolution spatiale de l'image (70cm) et sont donc totalement identifiables sur l'image (cf. Figure 1 et Figure 2).

L'image de Saint-Gilles (Gard) a été acquise le 19 juillet 2006 et celle de Vieux-Habitants (Guadeloupe) le 18 octobre 2007. Les caractéristiques de ces deux images sont détaillées dans les Table 1 et Table 2.




Figure 1 : Extrait de l'image Quickbird de St Gilles présentant différents vergers et vignes dont les arbres sont clairement identifiables (composition colorée PIR-Rouge-Vert obtenue à partir de l'image fusionnée à 70cm de résolution)



Figure 2 : Extrait de l'image Quickbird de Vieux Habitants présentant différents vergers tropicaux dont les arbres sont clairement identifiables (composition colorée PIR-Rouge-Vert obtenue à partir de l'image fusionnée à 70cm de résolution)

Image Quickbird	
Résolution	70 centimètres (fusionnée)
Nombre de colonnes	2411
Nombre de lignes	2122
Nombre de bandes	4 : Panchromatique Proche infra rouge Rouge Vert
Format de l'image	ENVI standard
Taille	19,5 Méga octets
MAP INFO	
Projection	UTM
Zone	31 Nord
Géoïde	WGS 84
Unités	Mètres
Coordonnées géographiques du centre	4°24'44.68"E 43°42'33.22"N

Table 1 :- Propriétés de l'image test 1 (Saint-Gilles)

Image Quickbird	
Résolution	70 centimètres (fusionnée)
Nombre de colonnes	968
Nombre de lignes	1248
Nombre de bandes	4 : Panchromatique Proche infra rouge Rouge Vert
Format de l'image	ENVI standard
Taille	18,4 Méga octets
MAP INFO	
Projection	UTM
Zone	20 Nord
Géoïde	WGS 84
Unités	Mètres
Coordonnées géographiques du centre	61°45'42.85"W 16°4'9.16"N

Table 2 : Propriétés de l'image test 2 (Vieux-Habitants)

### 2.3 Données de terrain et classification vérité-terrain

Toute classification d'image doit être confrontée à la réalité, c'est-à-dire à ce qu'il en est vraiment sur le terrain, pour être validée. Il est donc utile de définir des images de vérité-terrain à partir des connaissances de la zone d'étude, acquises par des observations directement sur le terrain ou par photointerprétation de photographies aériennes par exemple. Cette vérité-terrain est nécessaire aussi bien pour l'apprentissage que pour la validation de la méthode.

Une classification vérité-terrain de la zone de Saint-Gilles faisait partie des données à ma disposition dès le début de mon stage, établie suite à une enquête menée à la fin du mois de juin 2005. Cette image présente huit classes établies en fonction du type d'occupation du sol : champs, cultures maraîchères, forêts, friches, jeunes vergers (pêchers, abricotiers, nectariniers, cerisiers), vergers adultes (les même que "jeunes vergers" mais également des

oliviers et des amandiers), pommiers (vergers palissés) et vignes. L'image de classification vérité-terrain est présentée en Annexe 1.

Concernant la zone de Vieux-Habitants, seules des notes et des photographies recueillies sur le terrain en janvier 2008 étaient à ma disposition. J'avais également en ma possession un jeu de 27 coordonnées GPS (Cf. Annexe 3) avec, pour chacune, le type de plantation présente (manguiers, agrumes, goyavier, etc, ...). Sous le logiciel ENVI, j'ai donc créé une couche vectorielle constituée de ces points GPS, que j'ai ensuite superposée à l'image pour digitaliser les différentes parcelles par interprétation visuelle. J'ai ensuite affecté à chaque polygone ainsi créé un identifiant correspondant au type de verger indiqué dans les notes de terrain. J'ai ensuite regroupé les différents vergers par grand types similaires (forme et taille des arbres, structure et densité de la plantation...) et transformé cette couche vectorielle en image labélisée, constituant la classification de vérité terrain. Treize classes ont ainsi été identifiées : sols nus, zones herbacées, végétation avec forte densité, végétation avec faible densité, arbres de petites tailles, arbres de grosses tailles, arbres de grosses tailles avec forte densité, arbres âgés, agrumes, brise-vent, porte-greffes, palmiers, ainsi qu'une parcelle de troncs de manguiers. L'image de classification vérité terrain résultat est présentée en Annexe 2.

## CHAPITRE-3 METHODOLOGIE

### 3.1 Méthode de classification

#### 3.1.1 État de l'art

La classification d'image est un outil important pour l'interprétation des images de télédétection. Elle consiste en une traduction de l'information contenue dans les images en information thématique portant sur l'occupation du sol ou la couverture végétale (bâti, type de végétation, humidité du sol, etc, ...). Le processus de classification peut être décomposé en trois étapes principales : (1) établir les classes de descripteurs, (2) classer l'image à partir des classes de descripteurs, (3) évaluer la précision du résultat de classification. En fonction de la manière dont les classes de descripteurs sont établies, deux méthodes de classification s'opposent :

- la classification non dirigée (ex : K-means, ISODATA, classification ascendante hiérarchique...), dans laquelle les classes sont créées automatiquement suivant une similitude des signatures. La difficulté réside souvent dans l'interprétation a posteriori la nature des classes établies.
- la classification dirigée (ex : distance minimale à la moyenne, parallélepède, maximum de vraisemblance, distance de Mahalanobis, réseaux neuronaux...), qui nécessite une connaissance a priori de la zone à cartographier. Celle-ci est utilisée pour la création des classes en déterminant des zones d'entraînement ou échantillons d'apprentissage (petites surfaces isolées de l'image représentatives de la variabilité d'un thème observé), qui permettent d'entraîner l'algorithme de classification pour la reconnaissance des thèmes en fonction de leur signature spectrale sur l'image. Il est ensuite possible d'évaluer le résultat grâce à une matrice de confusion (comparaison du résultat avec des zones choisies indépendantes des zones d'entraînement).

Par ailleurs, il est possible d'utiliser (méthodes paramétriques, ex : le maximum de vraisemblance) ou non (méthodes non-paramétriques) des paramètres statistiques pour la séparation des classes. Généralement, ils reposent sur l'hypothèse d'une distribution gaussienne (distribution normale) des données. Un inconvénient important de ce type de méthode est la difficulté d'utiliser des informations spatiales et contextuelles, ou n'ayant pas de caractère statistique dans le processus de classification. Avec les méthodes non-paramétriques, telles que les réseaux de neurones, l'arbre de décision ou les SVM, l'hypothèse d'une distribution gaussienne des données ou d'autres paramètres statistiques ne sont pas nécessaires pour la séparation des différentes classes. De plus, contrairement aux méthodes paramétriques, l'utilisation d'information qui ne soit pas uniquement radiométrique dans le processus de classification est possible.

Même si d'une manière générale plusieurs approches existent dans le processus de classification [7], la plupart des algorithmes traditionnellement utilisés en télédétection reposent sur l'approche "pixel". Dans une telle approche, l'ensemble des pixels de l'image est classé à partir des signatures spectrales des pixels d'entraînement. Cependant, avec des données à THRS, il y a une augmentation considérable du nombre d'objets observés ainsi que des détails observés (l'ombre des objets par exemple) ce qui entraîne une grande variation spectrale. De plus, un objet est souvent défini sur plusieurs pixels ce qui engendre une discontinuité de l'information. Une approche "pixel" de classification avec des données à THRS ne permettrait pas d'obtenir de bons résultats sur des parcelles dont le contenu est varié (grand nombre de pixels de signature différente) même si l'ensemble présente une cohérence (type d'utilisation du sol unique). Elle ne sera donc pas retenue dans cette étude.

On retrouve dans la littérature d'autres approches qui s'opposent à celle-ci, comme l'approche orientée objet [8] : l'image est décomposée en objets homogènes par une segmentation. La classification est réalisée sur ces objets et non sur le pixel individuel. Une autre approche est la classification contextuelle [9] : elle tient compte de l'information spatiale



entre des pixels voisins ce qui permet d'améliorer le résultat des classifications [5]. Ces deux types d'approches semblent particulièrement adaptés aux données à THRS et c'est pourquoi la méthodologie proposée dans cette étude les combine. L'étape de segmentation est supposée réalisée, une couche vectorielle des parcelles étant utilisée pour les extraire. La classification est ensuite réalisée sur les parcelles en tant qu'objet. Des descripteurs caractérisant l'information globale de la parcelle sont alors définis pour permettre de les différencier (paramètres de texture et de la transformée de Fourier, indice de végétation..., cf. §3.2).

L'algorithme de classification doit donc accepter en entrée des données "vecteurs", constituées par les « parcelles » et permettre l'utilisation d'information de différentes natures, non uniquement radiométrique. Le choix de l'algorithme s'est donc porté sur les SVM qui est une méthode de classification supervisée et non-paramétrique.

### 3.1.2 L'algorithme de classification SVM

Cet algorithme de classification a été introduit par V. Vapnik en 1992 [10]. Il s'agit d'une méthode de classification binaire dont l'idée principale est de trouver un hyperplan séparant au mieux les données et dont la séparation (ou "marge", i.e. la distance séparant l'hyperplan du plus proche exemple) est la plus grande possible. Cette recherche correspond à un problème d'optimisation au cours duquel les exemples les plus proches de l'hyperplan, appelés vecteurs supports, sont sélectionnés. L'hyperplan calculé permet ainsi de séparer l'espace en deux zones. Nous donnons en Annexe 4 une présentation du principe mathématique pour des données linéairement séparables et comment cet algorithme peut s'étendre à des problèmes de classification où les données ne sont pas linéairement séparables grâce à l'utilisation de fonction noyaux.

Le SVM est par nature un classifieur binaire car il permet de séparer un espace en deux. Néanmoins, en télédétection on cherche rarement à discriminer deux classes uniquement; dans notre cas par exemple l'image test 1 comprend huit classes. On peut trouver dans la littérature plusieurs extensions des SVM au cas multi-classes [11,12], mais on peut se concentrer sur les deux principales :

#### 1) L'approche dite "*un contre tous*"

Cette méthode compare successivement une classe avec toutes les autres au moyen d'un classifieur binaire. Si on a  $n$  classes,  $n$  classifieurs binaires sont construits ( $n$  hyperplans, soit  $n$  problèmes d'optimisation), le  $n$ -ième classifieur étant destiné à distinguer la classe d'indice  $n$ . Chaque élément à classifier est donc présenté aux  $n$  classifieurs et se voit attribuer l'étiquette du classifieur ayant renvoyé le plus grand pourcentage d'appartenance. Dans [13], il est soutenu qu'une telle approche, en plus d'être simple, permet d'obtenir des performances qui ne sont pas significativement inférieures à celles des autres méthodes des SVM multi classes lorsqu'elle est correctement paramétrée.

#### 2) L'approche "*un contre un*"

Cette approche, développée par [14], consiste à chercher toutes les paires de classes possibles et aboutit à un classifieur par paire. Autrement dit, si on a  $n$  classes on aboutit à  $n(n-1)/2$  hyperplans. Le classifieur indicé par le couple  $(k,l)$  est destiné à distinguer la classe d'indice  $k$  de celle d'indice  $l$ . Chaque élément à classifier est présenté à  $n(n-1)/2$  classifieur et obtient le label de la classe ayant eu le plus de vote. Il existe une référence de base pour l'analyse statistique de cette approche dans [15].

L'approche retenue pour la présente étude est celle "*un contre tous*" du fait de sa simplicité. En outre, elle est déjà implémentée dans ENVI, ce qui n'est pas le cas de l'approche « un contre un ».



### 3.1.3. Optimisation des SVM

L'élément important du SVM en approche non linéaire est qu'il repose sur l'utilisation d'une fonction noyau. Il existe un nombre très important de noyaux utilisés dans la littérature, dont plusieurs sont proposés pour inclure l'information spatiale [16]. Néanmoins, les quatre noyaux les plus fréquemment utilisés sont :

- Linéaire,
- Gaussien (Gaussian Radial Basic Function Kernel, RBF), qui serait d'après [17] le noyau à utiliser préférentiellement,
- Polynomial,
- Sigmoidal.

Nous avons donc retenu uniquement ces quatre noyaux pour cette étude, avec l'avantage qu'ils sont déjà implémentés dans ENVI. Ces noyaux possèdent des paramètres permettant d'ajuster la précision du résultat de classification, définis par l'utilisateur. Sous le logiciel ENVI, ces paramètres sont :

- le « penalty parameter », qui permet d'établir un compromis entre la minimisation de l'erreur d'apprentissage et la maximisation de la marge.
- le « pyramid level », permettant de créer des sous échantillons de l'image donc de réduire le temps de calcul (en augmentant sa valeur). Il est toutefois limité à un échantillon minimum de 64 x 64 pixels.
- le « classification probability threshold », seuil permettant de rendre la classification plus ou moins stricte en fonction d'une valeur de probabilité comprise entre 0 et 1.
- le « Gamma in kernel function », à définir uniquement pour les noyaux RBF, Polynomial et Sigmoidal, qui intervient dans la fonction noyaux.
- le biais des noyaux polynomial et sigmoidal.
- le degré du noyau polynomial.

Il n'existe pas de méthode bien établie pour fixer les valeurs idéales des ces paramètres. L'approche menée ici consiste à réaliser des séries de classifications en faisant varier les noyaux et leurs paramètres. Les matrices de confusion de chaque résultat sont ensuite analysées pour sélectionner le noyau le mieux adapté à notre problématique et optimiser ses paramètres.

## 3.2 Choix des descripteurs

Du fait de la très haute résolution des données, les parcelles présentent une hétérogénéité spectrale d'où la nécessité de tenir compte de leur contenu en information spatiale afin de les caractériser. De plus les parcelles arborées présentent un aspect structuré dû à la répétition des motifs caractéristiques des arbres qui est directement lié au mode de plantation et à la densité de plantation. La très haute résolution des données permet également d'avoir des informations sur la grosseur des différents arbres à travers la taille des motifs caractéristiques. Ces détails constituent autant d'éléments permettant de reconnaître les différents types d'arbres et qui nous ont amené à analyser les parcelles à travers leur texture. Dans [18], les auteurs ont utilisé des paramètres de texture dans une classification des cultures et ont noté une augmentation significative de la précision de la classification en intégrant l'information texturale dans le processus de classification.

### 3.2.1 Indices de texture

En télédétection, la texture est l'une des notions les moins rigoureuses. Le dictionnaire de la langue française donne la définition suivante pour la texture : « Constitution, agencement, disposition des différentes parties ou éléments d'un tout ». Dans une image, on peut donc la comprendre comme l'ensemble des caractéristiques d'une région qui apparaît globalement homogène mais présente des variations locales. Celles-ci peuvent être la répétition d'un motif de base ou primitive (ensemble de niveau de gris semblables) dont

l'agencement détermine le type de texture. En fonction de la structure de cet agencement, on distingue deux grands types de textures ;

1. Les textures aléatoires ou micro-textures, dans lesquelles aucun motif de base ne peut être isolé visuellement mais comprend une certaine homogénéité statistique (cf. Figure 3a). Leur structure spatiale est aléatoire.
2. Les textures structurées ou macro-textures, dont un ou plusieurs motifs de base peuvent être isolés et semblent se répéter plus ou moins régulièrement (cf. Figure 3b). L'organisation de ces textures est quasiment déterministe.




Figure 3 : Deux exemples de texture : a) micro-texture et b) macro-texture.

Dans notre cas, qui présente des couverts végétaux, on rencontre principalement des micro-textures et des textures mixtes car les objets ne sont jamais totalement identiques et leur organisation jamais strictement régulière. La Figure 4 montre par exemple un extrait de parcelle de vigne (a) et de forêt (b).




Figure 4: Deux exemples de texture extraites de l'image Quickbird de St Gilles : a) vigne et b) forêt.

Il existe de nombreuses approches d'analyse de texture plus ou moins adaptées à la télédétection et il serait difficile d'en faire une liste exhaustive. On en distingue cependant cinq grands groupes principaux:

- 1) les méthodes de filtrage, qui reposent sur l'utilisation de bancs de filtres multi-canaux, inspirées du système de perception visuelle humain qui décompose une image rétinienne en plusieurs réponses filtrées à différentes échelles et orientations. Le filtrage de Gabor [19] est l'une des plus utilisées, basée sur une onde sinusoïdale plane modulée par une enveloppe gaussienne. Les indicateurs de texture sont des paramètres énergétiques calculés sur les images filtrées avec des vecteurs d'onde de différentes orientations et normes.
- 2) les ondelettes [20], consistant en la transformation d'un signal dans le domaine spatial en un autre signal dans le domaine spatio-fréquentiel. Les coefficients du nouveau signal apportent des informations sur la variation locale des niveaux de gris autour d'un pixel donné. Plus ces coefficients sont grands, plus cette variation est importante.

- 3) les modèles fractals [21], qui sont une mesure du degré d'irrégularité d'un objet et se basent essentiellement sur l'estimation par des méthodes spatiales de la dimension fractale de la surface représentant les niveaux de gris de l'image.
- 4) les champs de Markov, qui permettent de modéliser les interactions entre des pixels à partir d'un modèle probabiliste. Il existe de nombreux modèles markoviens de texture : auto-binomial [22], auto-normal [23], ou encore de Derin et Elliot [24]. Ils peuvent modéliser des textures fines [25].
- 5) les matrices de cooccurrence [26], qui caractérisent les transitions de niveaux de gris dans un voisinage et dans une direction donnée. Elles formalisent mathématiquement les relations spatiales entre les niveaux de gris pris deux à deux. Les analyses reposent en général sur le calcul d'indices dérivés des statistiques du premier et second ordres de cette matrice, dont les quatorze plus usités ont été définis par Haralick [27], tels que l'énergie (second moment angulaire), le contraste (l'inertie), l'homogénéité (moment de la différence inverse), la corrélation, l'entropie, la moyenne...

C'est cette dernière qui est la plus populaire en raison d'une assez grande efficacité au regard de sa facilité de mise en œuvre [3, 5, 4, 28]. En particulier, ces indices renvoient des valeurs très contrastées sur des zones structurées ou macro-texturées, et sur celles qui présentent plutôt des textures stochastiques. Ils devraient donc être efficaces pour distinguer les parcelles arborées de celles qui ne le sont pas. Il semble en revanche plus délicat d'arriver à différencier différents types de structures de parcelles arborées.

Le logiciel ENVI calcule 8 indices de texture, dont certains apportent une information redondante ou sont très corrélés. Pour leur utilisation comme descripteurs pour une classification il est donc nécessaire d'en sélectionner les seuls réellement pertinents et non corrélés entre eux, par exemple à partir d'une analyse visuelle des indices rendant le mieux compte de la spécificité des textures des différents types de plantation. C'est ainsi le cas du **contraste**, dont la valeur augmente avec une plus forte variabilité des niveaux de gris dans la parcelle.

Deux paramètres importants déterminent le calcul des indices de texture :

- 1) la taille du voisinage dans lequel les transitions entre niveaux de gris sont analysées. Elle doit être représentative de la texture de la parcelle et donc contenir suffisamment de motifs caractérisant les arbres, sans pour autant être trop grande pour ne pas « noyer » ce motif et rendre sa détection impossible. Les éléments que l'on cherche à discriminer ont typiquement deux gammes de taille. Les arbres de vergers, d'environ 2m de diamètre et espacés d'environ 4m, dont le motif caractéristique en grille est composé de 4 arbres, occupent donc un voisinage de 13 pixels de côté. Les arbres de forêts sont plus gros et imposent une taille de voisinage de 25 pixels.
- 2) la direction dans laquelle les transitions sont recherchées. Nous avons retenu un angle de 45° avec un pas de 1 pixel, afin de tenir compte de ces informations apportées par les deux directions perpendiculaires.

Au final, un indice de texture est sélectionné comme descripteur : le **contraste** calculé suivant la direction de 45° et pour les deux tailles de voisinage de **13 et de 25 pixels**. Il est calculé sur toute l'image, puis la **moyenne** de chaque indice est extraite sur chaque parcelle.

### 3.2.2 Paramètres de Fourier

Les parcelles arborées possèdent des textures périodiques dues aux modes de plantation des arbres, schématiquement des grilles de points ou des lignes régulièrement espacées. Cela nous a orientés vers une analyse fréquentielle, qui devrait permettre d'établir une certaine typologie des différentes structures de plantation.

La transformée de Fourier, appliquée à une image qui est dans le domaine spatial, donne sa représentation dans le domaine de fréquence correspondant. Elle renvoie un nombre complexe possédant une amplitude et une phase. On s'intéresse alors essentiellement à la représentation de son amplitude, c'est à dire au spectre de Fourier, car elle contient la plus

grande partie de l'information sur la structure géométrique du domaine spatial de l'image. Ce spectre de Fourier se compose généralement de:

- un pic central qui représente la moyenne de l'image.
- des droites passant par le centre, dont la direction informe sur les directions dominantes de l'image d'origine (elles leur sont perpendiculaires). Plus une droite est longue, c'est-à-dire plus elle s'éloigne du centre, plus les fréquences qu'elle porte sont élevées.

En appliquant un seuil à ce spectre, éliminant les éléments de faible intensité donc de faible contribution à la structure spatiale de l'image, on fait apparaître des pics secondaires (cf. **Figure 5**) qui traduisent la périodicité d'un motif de l'image d'origine (si aucun pic ne ressort, il n'y a pas de motif périodique dans l'image). Cela implique que les paramètres qui décrivent le spectre de Fourier d'une parcelle arborée (**Figure 6**) sont porteurs d'une information sur la périodicité de sa texture [5, 29].







Figure 5 : Exemples de spectres de Fourier (b, d et f) d'images présentant des textures géométriques périodiques (a, c et e).






Figure 6 : Exemples de spectres de Fourier non filtré (au centre) et seuillé (colonne de droite) de parcelles d'arbres sans structure périodique (en haut), organisés en lignes (au milieu) et organisés en grille de points (en bas).

Les paramètres de Fourier qui nous apparus pertinents pour discriminer les différents types de parcelles arborées sont donc les suivants :

- 1) **le nombre de pics significatifs dans le spectre seuillé** : si uniquement deux pics symétriques ou aucun pic n'apparaissent, la structure est non périodique ; quatre pics alignés indiquent que la parcelle est structurée en lignes parallèles ; quatre pics ou plus non alignés sont caractéristiques d'une grille d'arbres individuels.
- 2) **l'angle de ces pics avec l'axe horizontal**, qui correspond à la direction de plantation par rapport à l'image
- 3) **la distance de ces pics au pic central**, égale aux largeurs des rangs et inter-rangs dans le cas de plantation en ligne et à la taille de la grille dans le cas où les arbres sont plantés selon ce motif. Ce paramètre devrait permettre d'accentuer la discrimination entre les parcelles de vergers et les autres types d'occupation du sol (champs, friches, forêts). Concrètement, ces paramètres ont été calculés à partir de la moyenne des transformées de Fourier locales appliquées à toutes les fenêtres de 64 pixels de côté incluses dans la parcelle [29].

### 3.2.3 NDVI

Il nous est finalement apparu intéressant d'introduire dans le processus de classification des indices permettant de caractériser l'âge des arbres ou la densité de végétation. En effet, ces caractéristiques n'impliquent pas forcément une variation du motif de plantation, mais ont une influence directe sur la radiométrie moyenne de la parcelle. Les indices de végétation permettant de caractériser ces paramètres de surface sont nombreux [30, 31, 32]. Nous avons sélectionné le plus couramment utilisé et connu pour être corrélé aussi bien à la biomasse qu'à l'activité chlorophyllienne du couvert végétal : l'indice de végétation de la différence normalisée ou NDVI.

Cet indice est calculé à partir des bandes rouge et infrarouge selon la formule  $NDVI = (PIR - R) / (PIR + R)$  sur chaque pixel de l'image, puis moyenné sur l'ensemble de la parcelle afin de n'obtenir qu'une seule valeur de NDVI globale sur celle-ci.

### 3.3 Analyse

Comme indiqué dans § 3.1.1, la classification n'est pas réalisée directement sur l'image Quickbird d'origine mais sur une nouvelle image composite dans laquelle chaque pixel correspond en réalité à une parcelle donnée de l'image de départ.

La couche vectorielle des parcelles créée à partir de la vérité-terrain permet effectivement d'extraire chacune d'elles ; on calcule ensuite les 6 descripteurs identifiés comme pertinents sur chacune de ces parcelles :

1. Contraste de la matrice de cooccurrence, voisinage de 13 pixels, orientation de 45°;
2. Contraste de la matrice de cooccurrence, voisinage de 25 pixels, orientation de 45°;
3. NDVI

4. Nombre de pics significatifs dans le spectre de Fourier,
5. Angle entre les pics significatifs du spectre de Fourier et l'axe horizontal,
6. Distance entre les pics significatifs du spectre de Fourier.

L'image de Vieux Habitants n'a pas pu être traitée à cause d'un obstacle technique non résolu durant la période du stage. En effet, le soft permettant le calcul des paramètres de Fourier crée par l'équipe possède un seuil ne prenant pas en compte les très grandes tailles des arbres tropicaux présents sur cette image.

L'analyse s'est donc portée sur l'image de Saint-Gilles. Un jeu de 179 parcelles a été extrait de cette image : 25 parcelles de champs, 14 parcelles de cultures maraîchères, 25 parcelles de forêts, 25 parcelles de friches, 15 parcelles de jeunes vergers, 25 parcelles de pommiers, 25 parcelles de vignes et 25 parcelles de vieux vergers (vergers adultes). Les 6 descripteurs sont donc calculés sur ces 179 parcelles. Le soft utilisé pour le calcul des paramètres de Fourier (nombre de pics, angle et distance des pics) ne permet pas de traiter les parcelles ne contenant pas de fenêtre de 30x30 pixels. Ces parcelles, au nombre de 36, sont éliminées du jeu de départ ; au final on dispose de 143 parcelles caractérisées par les 6 descripteurs, ce qui nous a permis de créer une nouvelle image de 1 colonne, 143 lignes et 8 bandes : la 1<sup>ère</sup> bande correspond aux indices des parcelles, la 2<sup>ème</sup> bande correspond aux labels correspondant aux classes, les 6 autres bandes correspondent aux descripteurs des parcelles. Ce jeu de données est divisé en deux (Table 3) : les données d'apprentissage et les données de validation.

Label	Occupation du sol	Parcelles d'apprentissage	Parcelles de validation	Total
1	Champs	10	10	20
2	Cultures Maraichères	5	6	11
3	Forêts	7	7	14
4	Friches	8	9	17
5	Jeunes Vergers	5	6	11
6	Pommiers	12	13	25
7	Vignes	12	12	24
8	Vieux vergers	8	13	21
Total		67	76	143

**Table 3 :- Répartition des parcelles du jeu de données.**

On applique alors la classification SVM sur cette nouvelle donnée, en faisant varier les noyaux de l'algorithme ainsi que certains paramètres dimensionnant ces noyaux :

Des analyses préliminaires ont montrées qu'une augmentation du paramètre de seuil (« probability threshold ») diminue les erreurs de classification (parcelles mal classées) mais augmente considérablement le nombre de parcelles non classées ce qui diminue la précision globale (overall accuracy) de la classification. Ce paramètre est donc fixé à 0, et les erreurs de classification vont permettre une analyse sur la pertinence des descripteurs ainsi que sur la possibilité de combiner certaines classes.

Des analyses préliminaires ont également révélées que la variation du paramètre « Gamma » est sans conséquence sur la précision globale des résultats. Sous le logiciel ENVI, la valeur de base de ce paramètre est égale à l'inverse du nombre de bandes, soit dans notre cas 1/6 (car se sont les 6 bandes correspondant aux descripteurs qui sont données en entrée à l'algorithme en plus du jeu d'apprentissage.).

Il n'est pas nécessaire de créer des sous échantillons de l'image pour réduire le temps de calcul car les l'image utilisée n'est pas de grande dimension. Le paramètre « pyramid level » est donc fixé à 0.

En fonction des noyaux utilisés, nous faisons varier les autres paramètres selon la Table 4.

Nous faisons varier le « penalty parameter » de 0 à 1000 avec un pas de 40. Nous prenons deux valeurs de biais (1 et 2) et deux valeur de degré (2 et 3) pour les noyaux nécessitant ces paramètres.

Noyau	« Penalty parameter »	Biais	Degré
RBF	0 - 1000	-	-
Linéaire	0 - 1000	-	-
Sigmoïdal	0 - 1000	1 et 2	-
Polynomial	0 - 1000	1 et 2	2 et 3

**Table 4 :- Noyaux et paramètres associés testés dans cette étude.**

Une telle analyse permettra de retenir pour chaque noyau les paramètres donnant les meilleurs résultats et de comparer ces résultats en fonction du noyau.


Ces résultats sont présenté au Chapitre 4.

## CHAPITRE-4 RESULTATS ET DISCUSSION

### 4.1 Matrices de confusion

#### Noyau RBF

En faisant varier le paramètre « penalty parameter » de 0 à 1000 avec un pas de 40, la précision globale de chaque résultat de classification est mesuré (Graphique 1).



**Graphique 1 :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter ». Noyau RBF.**

La meilleure précision (69,7368 %) est obtenue pour une valeur du « penalty parameter » égale à 320. Les résultats de classification obtenus avec cette valeur sont présentés sous forme de matrices de confusion construite à partir des données de validation (Table 5 et Table 6 ).

Précision globale		53/76	69,7368%						
Coefficient Kappa		0,6503							
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	8	0	0	0	0	0	0	0	8
Culture maraichère	0	2	0	0	0	0	0	0	2
Forêt	0	0	7	2	0	0	0	0	9
Friche	1	1	0	7	0	0	0	0	9
Jeune Verger	1	2	0	0	3	1	0	3	10
Pommier	0	1	0	0	0	11	2	4	18
Vigne	0	0	0	0	1	0	10	1	12
Vieux verger	0	0	0	0	2	1	0	5	8
Total	10	6	7	9	6	13	12	13	76




**Table 5 :- Matrice de confusion de la classification des données de validation. Noyau RBF, threshold = 0, gamma = 0,167, pyramid level = 0, penalaty parameter = 320.**

Précision globale	53/76	69,7368%							
Coefficient Kappa	0,6503								
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	80	0	0	0	0	0	0	0	10,53
Culture maraichère	0	33,33	0	0	0	0	0	0	2,63
Forêt	0	0	100	22,22	0	0	0	0	11,84
Friche	10	16,67	0	77,78	0	0	0	0	11,84
Jeune Verger	10	33,33	0	0	50	7,69	0	23,08	13,16
Pommier	0	16,67	0	0	0	84,62	16,67	30,77	23,68
Vigne	0	0	0	0	16,67	0	83,33	7,69	15,79
Vieux verger	0	0	0	0	33,33	7,69	0	38,46	10,53
Total	100	100	100	100	100	100	100	100	100

**Table 6 :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau RBF, threshold = 0, gamma = 0,167, pyramid level = 0, penalaty parameter = 320.**

### Noyau linéaire

Comme avec le noyau RBF, on fait varier le paramètre « penalty parameter » de 0 à 1000 (pas de 40) et la précision globale de chaque résultat de classification est mesurée (Graphique 2).



**Graphique 2 :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter ». Noyau linéaire.**

La meilleure précision (64,4737 %) est obtenue pour une valeur du « penalty parameter » égale à 80. Les résultats de classification obtenus avec cette valeur sont présentés sous forme de matrices de confusion construite à partir des données de validation (Table 7 et Table 8).

Précision globale	49/76	64,4737%							
Coefficient Kappa	0,5894								
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	5	0	0	0	0	0	0	0	5
Culture maraichère	0	2	0	0	0	0	0	0	2
Forêt	0	0	7	2	0	0	0	0	9
Friche	4	1	0	6	0	0	0	0	11
Jeune Verger	1	2	0	0	3	1	0	3	10
Pommier	0	1	0	0	0	11	2	4	18
Vigne	0	0	0	1	1	0	10	1	13
Vieux verger	0	0	0	0	2	1	0	5	8
Total	10	6	7	9	6	13	12	13	76


**Table 7 :- Matrice de confusion de la classification des données de validation. Noyau linéaire, threshold = 0, pyramid level = 0, penaltaty parameter = 80.**

Précision globale	49/76	64,4737%							
Coefficient Kappa	0,5894								
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	50	0	0	0	0	0	0	0	6,58
Culture maraichère	0	33,33	0	0	0	0	0	0	2,63
Forêt	0	0	100	22,22	0	0	0	0	11,84
Friche	40	16,67	0	66,67	0	0	0	0	14,47
Jeune Verger	10	33,33	0	0	50	7,69	0	23,08	13,16
Pommier	0	16,67	0	0	0	84,62	16,67	30,77	23,68
Vigne	0	0	0	11,11	16,67	0	83,33	7,69	17,11
Vieux verger	0	0	0	0	33,33	7,69	0	38,46	10,53
Total	100	100	100	100	100	100	100	100	100

**Table 8 :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau linéaire, threshold = 0, pyramid level = 0, penaltaty parameter = 80.**

### Noyau sigmoïdal

Avec ce noyau on fait varier le « penalty prameter » de 0 à 1000 (pas de 40) pour deux valeurs de biais différentes : 1 et 2 (Graphique 3). Des tests on révélés que pour une des valeurs de biais supérieur à 2, les précisions des classifications sont très mauvaises, c'et pour cette raison qu'on s'est limité à 2 pour la valeur de ce paramètre.



**Graphique 3 :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter » et pour des valeurs de biais égales à 1 et 2. Noyau Sigmoïdal.**

Avec un biais égal à 2, les précisions globales des classifications varient peu avec le « penalty parameter ». Les valeurs obtenues sont proches de 62% (à partir d'une valeur de 160 pour le « penalty parameter »). La meilleure précision globale de classification avec ce noyau est obtenue avec un biais de 1 et un « penalty parameter » égal à 440 (63,1575%). Les résultats de classification obtenus avec ces valeurs sont donc retenus (Table 9 et Table 10).

Précision globale		48/76	63,1575%						
Coefficient Kappa		0,5728							
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	9	1	0	5	0	0	0	0	15
Culture maraichère	0	2	0	0	0	0	0	0	2
Forêt	0	0	7	2	0	0	0	0	9
Friche	0	0	0	1	0	0	0	0	1
Jeune Verger	1	2	0	0	3	0	0	3	9
Pommier	0	1	0	0	0	12	2	5	20
Vigne	0	0	0	1	1	0	10	1	13
Vieux verger	0	0	0	0	2	1	0	4	7
Total	10	6	7	9	6	13	12	13	76


**Table 9 :- Matrice de confusion de la classification des données de validation. Noyau sigmoïdal, treshold = 0, pyramid level = 0, biais = 1, penaltaty parameter = 440.**

Précision globale		48/76	63,1575%						
Coefficient Kappa		0,5728							
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	90	16,67	0	55,56	0	0	0	0	19,74
Culture maraichère	0	33,33	0	0	0	0	0	0	2,63
Forêt	0	0	100	22,22	0	0	0	0	11,84
Friche	0	0	0	11,11	0	0	0	0	1,32
Jeune Verger	10	33,33	0	0	50	0	0	23,08	11,84
Pommier	0	16,67	0	0	0	92,31	16,67	38,46	26,32
Vigne	0	0	0	11,11	16,67	0	83,33	7,69	17,11
Vieux verger	0	0	0	0	33,33	7,69	0	30,77	9,21
Total	100	100	100	100	100	100	100	100	100

**Table10 :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau sigmoïdal, treshold = 0, pyramid level = 0, biais = 1, penalaty parameter = 440.**

### Noyau polynomial

Avec ce dernier noyau, on utilise les mêmes variations de « penalty parameter » et de biais que précédemment avec deux valeurs de degré pour le polynôme (2 et 3) (Graphique 4).



**Graphique 4 :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter » pour des valeurs de degré égales à 2 et 3, et des valeurs de biais égales à 1 et 2. Noyau polynomial.**

L'utilisation du noyau polynomial ici ne donne aucun résultat de classification se distinguant des autres par sa précision globale. Néanmoins on retient le meilleur résultat (65,7895%) obtenu avec un degré 2, un biais égal à 1 et un « penalty parameter » égal à 280 (Table 11 et Table 12).

Précision globale		50/76	65,7895%						
Coefficient Kappa		0,6044							
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	5	0	0	0	0	0	0	0	5
Culture maraichère	0	2	0	0	0	0	0	0	2
Forêt	0	0	7	1	0	0	0	0	8
Friche	4	1	0	7	0	0	0	0	12
Jeune Verger	1	2	0	0	3	1	0	3	10
Pommier	0	1	0	0	0	11	2	4	18
Vigne	0	0	0	0	1	0	10	1	12
Vieux verger	0	0	0	1	2	1	0	5	9
Total	10	6	7	9	6	13	12	13	76

**Table 11 :- Matrice de confusion de la classification des données de validation. Noyau polynomial, treshold = 0, gamma = 0,167, pyramid level = 0, degré = 2, biais = 1, penalyaty parameter = 280.**

Précision globale	50/76	65,7895%							
Coefficient Kappa	0,6044								
Classe de référence									
Classe	Champ	Culture maraichère	Forêt	Friche	Jeune Verger	Pommier	Vigne	Vieux verger	Total
Champ	50	0	0	0	0	0	0	0	6,58
Culture maraichère	0	33,33	0	0	0	0	0	0	2,63
Forêt	0	0	100	11,11	0	0	0	0	10,53
Friche	40	16,67	0	77,78	0	0	0	0	15,79
Jeune Verger	10	33,33	0	0	50	7,69	0	23,08	13,16
Pommier	0	16,67	0	0	0	84,62	16,67	30,77	23,68
Vigne	0	0	0	0	16,67	0	83,33	7,69	15,79
Vieux verger	0	0	0	11,11	33,33	7,69	0	38,46	11,84
Total	100	100	100	100	100	100	100	100	100

**Table 12 :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau polynomial, treshold = 0, gamma = 0,167, pyramid level = 0, degré = 2, biais = 1, penalyaty parameter = 280.**

## 4.2 Discussion

L'utilisation du noyau RBF a permis d'obtenir la meilleure classification avec une exactitude proche de 70% (Table 6). Il ressort cependant de toutes les matrices de confusion qu'il y a une bonne discrimination entre les parcelles de structures périodique, due au mode

de plantation des arbres (vergers, vignes, pommiers) et les autres types d'occupation du sol (champs, friches, forêts).

Les parcelles de forêt sont toujours classées avec une exactitude de 100%. L'analyse de la Table 6 montre que les champs sont classés avec une exactitude de 80%. Les 20% d'erreur sont classés en friche (10%) et en jeune verger (10%). Ceci peut s'expliquer par le fait que certains champs peuvent avoir un aspect désordonné, ce qui se rapproche de la texture des friches, ou un aspect de texture structuré en raison de la visibilité des traces de labour. La Table 6 montre également que les friches sont classées avec une exactitude d'environ 78% et que les 22% n'ont rien d'aberrant puisqu'ils sont classés en forêt et non dans des classes de parcelles de structures périodiques.

En ce qui concerne les parcelles de structures périodiques, on constate une exactitude d'environ 85% pour les pommiers. Les erreurs de classification se répartissent entre jeune verger et vieux verger, ce qui peut très bien se comprendre si on tient compte de l'âge de ces pommiers : des pommiers très jeunes ont une texture ainsi qu'un indice de végétation proche de celle des jeunes vergers, et de même des pommiers très vieux se rapprochent des vieux vergers. Les vignes sont également classées avec une bonne exactitude de l'ordre de 83%, les erreurs étant classées en pommier. Par contre les vieux vergers et les jeunes vergers ne sont pas classés avec de bonnes exactitudes (38% et 50% respectivement) malgré l'intégration de l'indice de végétation normalisé dans l'ensemble des descripteurs. Les erreurs de classification de ces classes se retrouvent en vigne, pommier, ou elle se confondent entre elles. Ceci s'explique par une variabilité de pratiques centrales induisant des distances de plantations et des densités qui peuvent être différentes. En particulier la classe " vieux vergers" comprend des espèces différentes (pêchers, abricotiers, cerisiers, ...) qui possèdent des structures de plantation légèrement distinctes.

## CHAPITRE-5 CONCLUSION ET PERSPECTIVES

Les objectifs de cette étude étaient d'évaluer le potentiel d'une classification basée sur l'algorithme SVM pour la discrimination des parcelles de vergers structurées avec les autres types d'occupation du sol, et pour la discrimination entre parcelles de vergers. La méthode a été mise en place en tenant compte de l'information spatiale des parcelles, mais également de l'information spectrale (NDVI). Des descripteurs pertinents ont été choisis pour caractériser au mieux l'information spatiale contenue dans les parcelles.

On constate que l'utilisation des SVM pour cette étude est adaptée, malgré une difficulté pour bien optimiser ses paramètres et permet d'obtenir des résultats satisfaisant en termes de discrimination des parcelles de type vergers avec les autres. Les vergers sont donc facilement isolables avec cette méthode. Néanmoins la précision de la discrimination entre les parcelles de vergers peut être améliorée.

Les résultats de cette étude s'ouvrent à de nombreuses perspectives :

Malgré la pertinence des descripteurs utilisés, il est nécessaire d'améliorer l'approche texture et structure, notamment pour les parcelles de vergers en définissant des descripteurs plus discriminants. On peut aussi diminuer le nombre de descripteurs caractéristiques des parcelles et tester la méthode avec les paramètres des SVM ayant donné de bon résultats. En effet le jeu de descripteurs doit certes être caractéristique, mais il ne doit pas être trop sélectif. Il s'agit de trouver un bon compromis entre précision globale et précision de classification.

Il serait par la suite intéressant d'appliquer la méthode sur la totalité des parcelles de l'image, ce qui permettrait d'avoir des jeux de données d'apprentissage et de validation plus importants, et également de remonter à l'image d'origine avec le résultat de classification afin d'obtenir une cartographie des parcelles de cette image.

Il est également important de régler les problèmes techniques n'ayant pas permis l'exploitation de l'image de Vieux Habitant afin d'évaluer la méthode sur d'autres zones, notamment les pays tropicaux où les arbres ainsi que leurs organisations sont différents. Il est également nécessaire de procéder à un regroupement de classes sur cette images qui possède à l'heure actuelle trop de classes ce qui rendrait sa classification particulièrement complexe. Les classes de cette image pourraient être regroupées de la manière suivante : zones non agricoles, brousse moyennement dense, brousse très dense, vergers de petites tailles, vergers de tailles moyennes, vergers de grosses tailles, arbres isolés.

Plus généralement, des améliorations de la méthode pourraient en faire un très bon outil pour la classification des vergers agricoles sur les données à THRS.

Sur le plan personnel, cette étude m'a beaucoup apportée. J'ai pris conscience de l'intérêt d'adapter les méthodes utilisées en traitement d'images satellites à l'augmentation des résolutions spatiales de ceux-ci. J'ai pu également mettre en pratique et améliorer les connaissances acquises sur le logiciel ENVI. Toujours sur le plan pratique, ce stage m'a permis de me familiariser encore un peu plus à la programmation, surtout avec IDL que j'ai utilisé pour mettre en place certains outils utiles. D'une manière générale, j'ai pu accroître mon goût pour la Télédétection.

## Liste des tableaux

**Table 1** :- Propriétés de l'image test 1 (Saint-Gilles)

**Table 2** :- Propriétés de l'image test 2 (Vieux-Habitants)

**Table 3** :- Répartition des parcelles du jeu de données.

**Table 4** :- Noyaux et paramètres associés testés dans cette étude.

**Table 5** :- Matrice de confusion de la classification des données de validation. Noyau RBF,  $\text{treshold} = 0$ ,  $\gamma = 0,167$ ,  $\text{pyramid level} = 0$ ,  $\text{penalty parameter} = 320$ .

**Table 6** :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau RBF,  $\text{treshold} = 0$ ,  $\gamma = 0,167$ ,  $\text{pyramid level} = 0$ ,  $\text{penalty parameter} = 320$ .

**Table 7** :- Matrice de confusion de la classification des données de validation. Noyau linéaire,  $\text{treshold} = 0$ ,  $\text{pyramid level} = 0$ ,  $\text{penalty parameter} = 80$ .

**Table 8** :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau linéaire,  $\text{treshold} = 0$ ,  $\text{pyramid level} = 0$ ,  $\text{penalty parameter} = 80$ .

**Table 9** :- Matrice de confusion de la classification des données de validation. Noyau sigmoïdal,  $\text{treshold} = 0$ ,  $\text{pyramid level} = 0$ ,  $\text{biais} = 1$ ,  $\text{penalty parameter} = 440$ .

**Table 10** :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau sigmoïdal,  $\text{treshold} = 0$ ,  $\text{pyramid level} = 0$ ,  $\text{biais} = 1$ ,  $\text{penalty parameter} = 440$ .

**Table 11** :- Matrice de confusion de la classification des données de validation. Noyau polynomial,  $\text{treshold} = 0$ ,  $\gamma = 0,167$ ,  $\text{pyramid level} = 0$ ,  $\text{degré} = 2$ ,  $\text{biais} = 1$ ,  $\text{penalty parameter} = 280$ .

**Table 12** :- Matrice de confusion de la classification des données de validation (pourcentage). Noyau polynomial,  $\text{treshold} = 0$ ,  $\gamma = 0,167$ ,  $\text{pyramid level} = 0$ ,  $\text{degré} = 2$ ,  $\text{biais} = 1$ ,  $\text{penalty parameter} = 280$ .



## Table des figures

**Figure 1 :** Extrait de l'image Quickbird de St Gilles présentant différents vergers et vignes dont les arbres sont clairement identifiables (composition colorée PIR-Rouge-Vert obtenue à partir de l'image fusionnée à 70cm de résolution).

**Figure 2 :** Extrait de l'image Quickbird de Vieux Habitants présentant différents vergers tropicaux dont les arbres sont clairement identifiables (composition colorée PIR-Rouge-Vert obtenue à partir de l'image fusionnée à 70cm de résolution).

**Figure 3 :** Deux exemples de texture : a) micro-texture et b) macro-texture.

**Figure 4:** Deux exemples de texture extraites de l'image Quickbird de St Gilles : a) vigne et b) forêt.

**Figure 5 :** Exemples de spectres de Fourier (b, d et f) d'images présentant des textures géométriques périodiques (a, c et e).

**Figure 6 :** Exemples de spectres de Fourier non filtré (au centre) et seuillé (colonne de droite) de parcelles d'arbres sans structure périodique (en haut), organisés en lignes (au milieu) et organisés en grille de points (en bas).

**Figure 7 :** Exemple de données linéairement séparables.

**Figure 8 :** Maximisation de la marge.

**Figure 9 :** Exemples de données non linéairement séparables.

## Liste des graphiques

**Graphique 1** :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter ». Noyau RBF.

**Graphique 2** :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter ». Noyau linéaire.

**Graphique 3** :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter » et pour des valeurs de biais égales à 1 et 2. Noyau Sigmoidal.

**Graphique 4** :- Variation de la précision globale des classifications en fonction du paramètre « penalty parameter » pour des valeurs de degré égales à 2 et 3, et des valeurs de biais égales à 1 et 2. Noyau polynomial.

## BIBLIOGRAPHIE

- [1] Cushnie J.L., 1987: The interactive effects of spatial resolution and degree of internal variability within land-cover on classification accuracies, *International Journal of Remote Sensing*, vol. 8, n.1, pp 15-29.
- [2] J. Irons and Toll, 1985: Performance comparisons between techniques using variable information extraction techniques using variable spatial resolution data, *Photogrammetric Engineering and Remote Sensing*, 51 (9): 1495-1470.
- [3] Flygare, A-M., 1997, A comparison of contextual classification methods Using Landsat TM. *International Journal of Remote Sensing*, 18, PP. 3835-3842.
- [4] Gordon D. K., Philipson W. R, 1986 : A texture enhancement procedure for separating orchard from forest in Thematic Mapper data, vol.7, n.2, pp 301-304.
- [5] C. Delenne, S. Durrieu, G. Rabatel, M. Deshayes, J.-S. Bailly, C. Lelong, P. Coueron, 2008: «Textural approaches for vineyard detection and characterization using very high spatial resolution remote-sensing data», *International Journal of Remote Sensing*, 29 (4), 1153-1167.
- [6] T. Kombe, R.J. Assato Assato, 2007: Mathematical morphology applied to SAR images for the detection of urban areas: the case study of the city of Douala. *Revue Télédétection*, vol. 7, n. 1-2-3-4, pp 251-270.
- [7] D. LU and Q. Weng, 2007. A survey classification methods and techniques for Improving classification performance. *International Journal of Remote Sensing*. Vol. 28, Nos. 5-6, , 823-870.
- [8] Thomas, N., Hendrix, C. and Congalton, R.G, 2003, A Comparison of urban Mapping methods using high-resolution digital imagery. *Photogrammetric Engineering and Remote Sensing*, 69, PP. 963-972.
- [9] Gong, P. and Howarth, P.J.,1992, Frequency-based contextual classification And gray-level vector reduction for land-use identification. *Photogrammetric Engineering and Remote Sensing*, 58, PP. 423-437.
- [10] B.E. Boser, I.M. Guyon, V. Vapnik, 1992 : A training algorithm for optimal margin classifiers, Proc. Fifth Ann. Workshop computational learning theory, ACM Press, pp 144-152.
- [11] Y. Guermeur, A. Elisseell, and D. Zelus, 2005: A comparative study of multi-class Support vector machines in the unifying framework of large margin Classifiers. *Applied Stochastic Models in Busines and Industry*,2, PP. 199-214.
- [12] J. Weston and C. Watkins, 1998: Multi class support vector Machines. Royal Holloway, University of London, Departement of Computer Science.
- [13] R. Rifkin and A. Klautau, 2004: In defense of one-vs-all classification. *Journal of Machine Learning Research*, 5 : 101-141.
- [14] S. Knerr, L. Personnaz, and G. Dreyfus, 1990: Single-layer learning revisited: A Stepwise procedure for building and training a neural network. In F. Ergelman- Soulié

and J. Héroult, editors, *Neurocomputing: Algorithms, Architectures and Applications*, vol. F68 of *NATO ASI Series*, pp 41-50. Springer-Verlag.

- [15] J. Friedman, 1996: Another approach to polychotomous classification. Technical Report, Departement of Statistics, Stanford University.
- [16] G. Camps-Valls, L. Gomez-Chova, J. Munoz-Mari, J. Vila-Francés, and J. Calpe-Maravilla, 2006 : Composite Kernels for hyperspectral image classification. *IEEE Geosci. Remote Sensing Letters*, 3(1): 93-97.
- [17] C-W. HSU, C-C., Chang and C-J. Lin, 2008: A pratical Guide to Support Vector Classification.
- [18] Anys, H. and He, D.-C., 1995: Evolution of textural and multipolarization Radar for crop classification. *IEEE Transactions on Geosciences and Remote Sensing*, pp 1169-1181.
- [19] M. Idrissa et Mare Acheroy, 2002 : Texture classification using Gabor filters. *Pattern Recognition letters*, 23(9): 1095-1102.
- [20] Laine, J. Fan, 1996: "Frame Representation for Texture Representation", *IEEE Trans. Img. Processing*, vol. 5, no.5, pp 771-780.
- [21] M. Dikking, J. Levy Vehel, E. Lutton et C. Tricot. *Fractals*, 1999 : Theory and application in engineering. Springer.
- [22] J. Besag, 1974: Spatial interaction and the statistical analysis of Lattice systems. *J. Roy. Stat. Soc. B*, 36: 192-236.
- [23] R. Chellappa, S. Chatterjee, R. Bagdazian, 1985: Texture synthesis and compression using Gauss-Markov random fields, *IEEE Transactions on Systems, Man, and Cyberetics*, 8(2), pp 298-303.
- [24] H. Derin and H. Elliot., 1987: Modeling and segmentation of noisy and textured images using Gibbs random fields. *IEEE. Trans. On Pattern Anal. and Mach.* 721-741.
- [25] Crimmins T. R., 1980: Geometric filter for speckle reduction. *Applied Oplics*, vol. 24, n.10, pp 1438-1443.
- [26] R. M. Haralick, 1979 : Statistical and structural approaches to texture. *Proc. IEEE*, 67(5):786–804.
- [27] R. M. Haralick, K. Shanmugam, et I Dinstein, 1973 : Textural features for image classification. *IEEE Transaction on Systems, Man, and Cybernetics*, 3:610–621.
- [28] C. Lelong et A. Thong-Chane, 2003: "Application of textural analysis on very high resolution panchromatic images to map coffee orchards in Uganda", *Proceedings of the IGARSS*, II, 1007-1009, Toulouse (FR), 21-25 juillet 2003.
- [29] B. Mougél et C. Lelong, 2008 : « Classification and Information Extraction in Very High Resolution Satellite Images for Tree Crops Monitoring ». *28<sup>ième</sup> Symposium EARSEL*, Istanbul, Turquie.
- [30] Tucker, C.J., 1979 Red and photographic infrared linear combinations for monitoring vegetation. *Remote Sensing of Environment* , 8, 127-150.

- [31] Cihlar, J.; St-Laurent, L.; Dyer, J., 1991: Relation between the normalized vegetation index and ecological variables. *Remote Sensing of Environment*, 35, 279-298.
- [32] Baret, F.; Guyot, G., 1991 : Potentials and limits of vegetation indexes for LAI and APAR assessment, *Remote Sensing of Environment*, 35 (2-3), 161-173.


## **ANNEXES**

## Annexe 1: Cartes présentant la zone d'étude de Saint-Gilles (Gard)





# Classification de verite-terrain



- Parcelles non classees (bati, routes, surfaces indefinies)
- Jeunes vergers
- Pommiers
- Vergers adultes
- Vignes
- Clatures maraicheres
- Forets
- Friches
- Champs

0 0,1 Kilometres

↑  
Nord



**Annexe 2: Cartes présentant la zone d'étude de Vieux-Habitants (Guadeloupe)**

**Composition coloree faisant intervenir les bandes  
vert, rouge et infrarouge**

↑  
**Nord**



0 0.1  
Kilometres



## Classification de verite-terrain



- Non classe
- troncs de manguiers
- Arbres de petite taille
- Arbres de grosse taille
- Porte-greffes
- Zones herbacees
- Sols nus
- Arbres ages
- Vegetation avec forte densite
- Vegetation avec faible densite
- Brise-vent
- Arbres de grosse taille avec forte densi
- Agrumes
- Rang de palmiers

↑  
Nord

**Annexe 3: Coordonnées GPS des points relevés sur le terrain dans la zone de la station fruitière de Vieux-Habitants.**

GROUPE	LONGITUDE	LATITUDE
Cerise-des-antilles	-61.7586722222	16.0669750000
Manguiers	-61.7611361111	16.0632611111
Caimite	-61.7609277778	16.0658833333
Manguiers	-61.7621333333	16.0635555556
brise-vent	-61.7580944444	16.0671277778
Bananiers	-61.7601750000	16.0629111111
Tamarins	-61.7597555556	16.0663222222
Agrumes	-61.7603861111	16.0631944444
Spondias monbin	-61.7626333333	16.0640361111
Agrumes	-61.7621888889	16.0634222222
Agrumes	-61.7619444444	16.0632805556
Longanes	-61.7621250000	16.0627944444
Agrumes	-61.7597555556	16.0663222222
Pitayas et pomme-cannelle	-61.7566722222	16.0679694444
Manguiers	-61.7566111111	16.0678250000
Agrumes	-61.7619555556	16.0633527778
Manguiers	-61.7589972222	16.0664944444
Acacias	-61.7597555556	16.0663222222
Goyaviers	-61.7625361111	16.0642472222
Support à vanilliers	-61.7599972222	16.0623833333
Corosols	-61.7597555556	16.0663222222
Anacardiers	-61.7597555556	16.0663222222
Manguiers	-61.7614166667	16.0625777778
Cerises-de-cayenne	-61.7597555556	16.0663222222
Manguiers	-61.7580527778	16.0669944444
Cerise-des-Antilles	-61.7581194444	16.0672583333
Sapotille	-61.7597555556	16.0663222222

## Annexe 4 : Principe mathématique du classifieur basé sur le Séparateur à Vaste Marge (SVM)

### 1. Données linéairement séparables

Considérons un ensemble d'entraînement

$$S = \{(\mathbf{x}_1, y_1), \dots, (\mathbf{x}_i, y_i)\} \in \mathbb{R}^n \times \{-1, 1\} \quad (1)$$

avec  $\mathbf{x}_i$  les vecteurs en entrée,  $y_i$  le label de classe du vecteur  $\mathbf{x}_i$  (dans le cas d'un problème binaire  $y_i$  a pour valeur -1 ou 1).

On émet l'hypothèse que  $\mathbb{R}$  est muni d'un produit scalaire, noté  $\langle \cdot, \cdot \rangle$ , et que les données sont linéairement séparables (Figure 7).




Figure 7 : Exemple de données linéairement séparables

L'algorithme recherche pour ces données l'hyperplan qui maximise la marge pour l'ensemble d'apprentissage. Cet hyperplan est paramétré par :

$$\langle \mathbf{x}, \mathbf{w} \rangle + b = 0 \quad (2)$$

$\mathbf{w}$  étant un vecteur de poids et  $b$  un biais.

On a donc la fonction de décision suivante :

$$y = f(\mathbf{x}) = \text{sign}(\langle \mathbf{x}, \mathbf{w} \rangle + b) \quad (3)$$

Cette fonction de décision est invariante par changement d'échelle, d'où l'hyperplan canonique donné par

$$\langle \mathbf{x}, \mathbf{w} \rangle + b = 1 \text{ et } \langle \mathbf{x}, \mathbf{w} \rangle + b = -1 \quad (4)$$

Sur les hyperplans de marge (hyperplans parallèles à l'hyperplan optimal et passant par les vecteurs supports). (Figure 8). La marge étant donnée par  $1/\|\mathbf{w}\|$ , avec  $\|\mathbf{w}\|^2 = \langle \mathbf{w}, \mathbf{w} \rangle$ , le problème d'optimisation revient à minimiser

$$\frac{1}{2}\|\mathbf{w}\|^2 \text{ avec } y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) \geq 1 \text{ pour } i = 1, \dots, n \quad (5)$$

De la même manière, le Lagrangien du problème est

$$L(\mathbf{w}, b, \alpha) = \frac{1}{2}\|\mathbf{w}\|^2 - \sum_{i=1, n} \alpha_i (y_i(\langle \mathbf{w}, \mathbf{x}_i \rangle + b) - 1) \quad (6)$$

Où  $\alpha_i > 0$ ,  $i = 1, \dots, n$  sont les multiplicateurs de Lagrange. Ainsi,  $L(\mathbf{w}, b, \alpha)$  doit être minimisé en  $\mathbf{w}$  et  $b$  et maximisé en  $\{\alpha_i\}$ . La minimisation en  $\mathbf{w}$  et  $b$  s'effectuant analytiquement, le problème d'optimisation dual s'écrit :

$$\text{Maximiser } W(\alpha) = \sum_{i=1,n} \alpha_i - \frac{1}{2} \sum_{i=1,n} \sum_{j=1,n} \alpha_i \alpha_j y_i y_j < x_i, x_j >$$

Avec  $\alpha_i \geq 0, i = 1, \dots, n$  (7)

Et  $\sum_{i=1,n} \alpha_i y_i = 0$

La minimisation de  $\alpha$  étant effectuée numériquement,

$$w = \sum_{i=1,n} \alpha_i x_i$$

(8)

La fonction de décision du problème s'écrit finalement comme suit

$$f(x) = \text{sign} \left( \sum_{i=1,n} y_i \alpha_i < x, x_i > + b \right)$$

(9)

$x$  étant le vecteur à classifier et  $x_i$  le vecteur d'apprentissage.




Figure 8 : Maximisation de la marge

## 2. Données non linéairement séparables

La plus part du temps on ne peut pas séparer les données de manière linéaire (Figure 9). L'utilisation de fonctions noyaux permet alors d'étendre le champ d'application des SVM à des problèmes de classification où les données ne sont pas linéairement séparables. Concrètement, le problème est résolu par le passage à un espace de dimension plus grande où les données deviennent linéairement séparables. Formellement, le produit scalaire est remplacé par un noyau dans les expressions précédentes. Ainsi, la fonction de décision du problème devient :

$$F(x) = \text{sign} \left( \sum_{i=1,n} y_i \alpha_i K(x, x_i) + b \right)$$

(10)




Figure 9 : Exemples de données non linéairement séparables

Au final, les paramètres de cette fonction de décision sont obtenus en résolvant (au lieu de (7)):

$$\begin{aligned}
 &\text{Maximiser } W(\alpha) = \sum_{i=1,n} \alpha_i - \frac{1}{2} \sum_{i=1,n} \sum_{j=1,n} \alpha_i \alpha_j y_i y_j k(\mathbf{x}_i, \mathbf{x}_j) \\
 &\text{Avec } \alpha_i \geq 0, i = 1, \dots, n \\
 &\text{Et } \sum_{i=1,n} \alpha_i y_i = 0.
 \end{aligned} \tag{11}$$